

ارزیابی و مقایسه روش‌های الگوهای مکانی مشترک و قطعه‌بندی هوشمند در آشکارسازی **P300** مؤلفه

زهرا امینی^۱, وحید ابوطالبی^۲ و محمد تقی صادقی^۳

۱- کارشناس ارشد، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد- یزد- ایران

zamini@stu.yazduni.ac.ir

۲- استادیار، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد- یزد- ایران

abootalebi@yazduni.ac.ir

۳- استادیار، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد- یزد- ایران

m.sadeghi@yazduni.ac.ir

چکیده: هدف از این مقاله ارزیابی دو روش قطعه‌بندی هوشمند و الگوهای مکانی مشترک به عنوان دو راهکار استخراج ویژگی در سیستم‌های آشکارسازی مؤلفه P300 است. بدین منظور، یک سیستم مبتنی بر بازناسانی آماری الگو طراحی شد. در این سیستم که با دادگان P300-Speller مسابقات BCI 2005 کار می‌کند، پس از اعمال پیش‌پردازش‌های اولیه، دو دسته ویژگی قطعه‌بندی هوشمند و الگوهای مکانی مشترک از دادگان استخراج گردید. این ویژگی‌ها از دو دیدگاه تکی (با آزمون t-test) و گروهی (با استفاده از درصد صحت طبقه‌بندی کننده LDA و انتخاب ویژگی به روش تحلیل تفکیکی گام به گام و محاسبه درصد صحت با طبقه‌بندی کننده SWLDA) سنجش شدند که در نهایت، دسته ویژگی قطعه‌بندی هوشمند با کسب بالاترین درصد صحت (۹۵٪/۲۵٪) به عنوان روش برتر انتخاب شد.

واژه‌های کلیدی: استخراج ویژگی، الگوهای مکانی مشترک، طبقه‌بندی کننده، قطعه‌بندی هوشمند، مؤلفه P300.

میانگین گرفت تا قسمت نویز تصادفی EEG تضعیف شود و بتوان در میان آن سیگنال ERP را مشاهده نمود.^[۱] تقریباً تمامی مطالعات انجام شده در مورد ERP‌ها، P300 را بر جسته‌ترین مؤلفه در بین مؤلفه‌های شناختی مختلف موجود در سیگنال‌های مغزی می‌دانند. P300 نوع خاصی از ERP و یا به تعبیر دیگر، مؤلفه‌ای از ERP است که در موقعیت خاصی ظاهر می‌شود. طبق تحقیقات انجام شده، هنگامی که مغز هنگام پردازش یک سری از تحریکات معمول، به یک تحریک غیرمعمول (تحریک هدف) بر می‌خورد، در سیگنال مغزی ثبت شده، یک موج P300 ظاهر می‌شود.

از لحاظ فیزیکی، P300 دارای قطبیت مثبت و دامنه حدود ۱۰ تا ۱۵ میکروولت (در افراد جوان) است. برای تحریک‌های صوتی، میزان تأخیر موج P300 به طور متوسط

۱- مقدمه Danielovsky در سال ۱۸۷۷ و Marcow در سال ۱۸۸۳ از نوعی سیگنال EEG خبر دادند که در موقعیت تحریک شخص و یا وقوع یک رخداد ظهور می‌کند و به همین علت، این پتانسیل‌ها، وابسته به رخداد یا به اختصار ERP نام گرفتند. دامنه این سیگنال به قدری ضعیف است (از مرتبه ۰/۰۱ دامنه سیگنال EEG معمولی) که برای مشاهده آن نیاز است تعداد زیادی از آنها را با یکدیگر

^۱ تاریخ ارسال مقاله : ۱۳۹۰/۳/۱۲
تاریخ پذیرش مقاله : ۱۳۹۰/۱۱/۱۶
نام نویسنده مسؤول : زهرا امینی
نشانی نویسنده مسؤول : ایران - اصفهان- خیابان هزار جریب
کوی امام جعفر صادق - بوستان ۴ شرقی- پلاک ۱۱
کد پستی ۸۱۷۴۶۶۳۷۷

است که حالت ذهنی شخص را به صورت مستقیم به سیگنال‌های کنترل و ارتباطی تبدیل می‌کند.

کاربردهای BCI تاکنون به دو دسته کلی توانبخشی برای افراد معلول حرکتی و سرگرمی برای افراد سالم تقسیم شده است. BCI برای افراد معلول به منظور کنترل اندام مصنوعی، کنترل صندلی چرخدار، کنترل نشانگر یک یا دو بعدی در صفحه رایانه و کنترل صفحه کلید مجازی به کار رفته است، اما کاربرد آن برای افراد سالم هم اینکه به بازی‌های سه بعدی در محیط‌های مجازی و در آزمایشگاه‌ها محدود می‌شود.

در کارهای online و شبیه‌سازی‌های offline، الگوریتم‌های متفاوت و متنوعی (مثل: آنالیز مؤلفه‌های مستقل (ICA)^۵ [۶]، تبدیل موجک [۷]، آستانه‌گذاری و بازناسانی آماری الگو [۸] (شامل روش‌های مختلف استخراج ویژگی و طبقه‌بندی)) برای تشخیص سیگنال‌های P300 به کار گرفته شده است. براساس این تحلیل‌ها، سیستم‌های BCI مبتنی بر P300، امروزه نرخ ارتباطی برابر با یک کلمه (یعنی پنج حرف) در هر دقیقه را دارند و در آینده پیشرفت‌های قابل ملاحظه‌ای در سرعت آنها، ممکن خواهد بود.

همچنین از سال ۲۰۰۰ مسابقاتی با عنوان BCI Competition به صورت دو سالانه برگزار می‌شود که یکی از بخش‌های این مسابقه یک سیستم P300-speller است که در آن از مؤلفه P300 برقراری ارتباط بین مغز و رایانه، از طریق انتخاب حروف از روی یک صفحه کلید رایانه، استفاده می‌شود [۹]. از زمان برگزاری این مسابقات تاکنون، بسیاری از افراد و گروه‌های پراکنده که قصد کارکردن روی مسئله آشکارسازی P300 را داشته‌اند از این دادگان استفاده کرده‌اند. از جمله افرادی که با استفاده از این دادگان به نتایج خوبی رسیده‌اند، می‌توان به موارد زیر اشاره کرد:

Neng Xu در مسابقه BCI2003 از آنالیز مؤلفه‌های مستقل (ICA) برای آشکارسازی P300 استفاده کرد تا هم منابع مستقل سیگنال را از هم جدا کند و هم قطعات زمانی مشکوک را از میان بردارد. وی با استفاده از دو ویژگی پیک (قله) سیگنال و همچنین، متوسط سیگنال در بازه زمانی ۲۷۵

حدود 300ms است که علت انتخاب نام P300 نیز به علت قطیبت مثبت و تأخیر 300ms آن بوده است. ولی برای تحریکات دیگر، مثلاً تحریک تصویری، این زمان ممکن است تا حدود 1000ms هم افزایش یابد؛ اگرچه در هر حال، این موج به عنوان P300 نامیده می‌شود. در کل، در تعریف P300، تأخیری بین ۳۰۰ تا ۱۰۰۰ میلی ثانیه برای آن ذکر می‌شود.

با توجه به ارتباط تنگاتنگی که بین بروز مؤلفه P300 و فعالیت شناختی مغز وجود دارد، از این مؤلفه در تحقیقاتی که به نحوی با جنبه شناختی فعالیت مغز سر و کار دارند، از جمله در کارهای کلینیکی برای تشخیص بیماری‌های مانند آلزایمر، اعتیاد به الکل، اوتیسم، اسکیزوفرنی و MS و تشخیص میزان خستگی سوژه [۲] استفاده شده است. از کاربردهای دیگری که برای P300 مطرح شده، استفاده از این مؤلفه شناختی به منظور دروغ سنجی است. در این کاربرد، نحوه آزمون باید طوری طرح شود که بتواند به صورت یک الگوی Oddball عمل کند؛ یعنی سوژه از بین چند مورد سؤال (مثلاً ۵ مورد) تنها به یک مورد حساس باشد و هدف نیز تشخیص همین مورد از روی سیگنال‌های مغزی او باشد. در این زمینه نیز کارهایی، خصوصاً به وسیله Donchin و Rosenfeld در سال ۲۰۰۶ نیز ابوطالبی با ارزیابی آزمون‌های مختلف دروغ سنجی، پروتکلی بر مبنای بروز P300 در فرد خطاکار در رویارویی با تحریک مرتبط با جرم طراحی کرد. وی با ارزیابی روش‌های مختلف طبقه‌بندی، LDA^۳ را به عنوان طبقه‌بندی کننده بهینه در تفکیک این دادگان برگزید و در نهایت، درصد صحت ۸۶٪ در تفکیک افراد خطاکار و بی‌گناه حاصل شد [۵].

یکی از کاربردهای مهم سیگنال EEG و مؤلفه P300 در سیستم‌های واسط مغز با رایانه (BCI)^۴ است. هدف یک سیستم BCI برقراری ارتباطی میان مغز کاربر و رایانه برای انتقال منظور وی به دنیای خارج، بدون استفاده از خروجی‌های عصبی و ماهیچه‌ای است. یک سیستم BCI مجموعه‌ای از حسگرها و وسایلی برای ثبت و پردازش سیگنال مانند نمایشگر، تحریک کننده‌های حسی و رایانه

و P4, Pz, Cz, Fz و حداکثر ۶۰ ویژگی مدل، صحت ۹۲٪ به دست آمده است.^[۱۲]

و همکارانش^[۱۳] در سال ۲۰۰۹ طی تحقیقی روی دادگان P300 مسابقات ۲۰۰۵ BCI، از تبدیل موجک گستته برای استخراج ویژگی‌های سیگنال مغزی استفاده کردند. آنها با قطعه‌بندی دادگان ورودی طبقه‌بندی کننده، برای هر قطعه از یک FLD^۹ استفاده کردند. سپس نمره هر طبقه‌بندی کننده حساب شده و این نمره‌ها جمع شده است تا بهترین رتبه برای قطعه به دست آید (Ensemble of FLDS). این گروه توانست با این روش به صحت میانگین ۹۵٪ دست یابد.

در این مقاله، هدف آن است تا توسط یک سیستم مبتنی بر بازناسانی آماری الگو به آشکارسازی مؤلفه P300 پرداخته شود و ضمن آن کارایی دو روش نسبتاً جدید استخراج ویژگی، شامل قطعه‌بندی و الگوهای مکانی مشترک^{۱۰} (CSP) نیز ارزیابی و با یکدیگر مقایسه گردد. همچنین، اثر ترکیب دو روش فوق در افزایش یا کاهش میزان صحت سیستم بررسی خواهد شد. بدین منظور، پس از معرفی دادگان مورد استفاده و پیش‌پردازش‌های صورت گرفته بر روی آن، هر یک از این روش‌های استخراج ویژگی، شرح داده خواهند شد و در ادامه با به‌کارگیری دو دیدگاه تکی و گروهی این ویژگی‌ها ارزیابی و دسته ویژگی کاراتر در آشکارسازی مؤلفه P300 مشخص خواهد شد. نهایتاً نتایج حاصل در قسمت آخر بیان می‌گردد.

۲- دادگان مورد استفاده

بسیاری از گروه‌های تحقیقاتی که بر روی مسئله آشکارسازی مؤلفه P300 کار می‌کنند، از دادگانی استفاده می‌کنند که برای مسابقات BCI فراهم شده است.^[۹] در این مقاله نیز سیگنال‌هایی استفاده می‌شوند که به وسیله گروه وادثوثر و در چهارچوب BCI2000 تهیه شده‌اند و از راه سایت اینترنتی مسابقه BCI2005 در اختیار قرار گرفته‌اند. در این آزمایش یک جدول با ابعاد ۶×۶ حاوی ۳۶ کاراکتر (مطابق شکل ۱) در مقابل فرد وجود دارد. یک کلمه (به

تا ۳۷۰ میلی‌ثانیه به میزان صحت ۱۰۰٪ در تشخیص کاراکتر رسید.^[۶]

Kaper در مسابقه BCI2003 با استفاده از ماشین بردار بشتبیان^۷ (SVM) با هسته گوسی توانست به صحت ۱۰۰٪ در تشخیص کاراکتر برسد. وی سیگنال ۱۰ کاناله از زمان اعمال تحریک تا ۶۰۰ میلی ثانیه بعد را به عنوان ویژگی به کار برد.^[۸]

Hoffmann نیز در تحقیقی در سال ۲۰۰۵ روش Boosting را برای آشکارسازی P300 در دادگان مسابقه BCI2003 بررسی کرد. وی با متوسط‌گیری روی چهار بار تکرار تحریک ماتریس P300-speller در تشخیص کاراکتر به میزان صحت ۱۰۰٪ دست یافت.^[۱۰]

Yang Liu در مقاله‌ای در سال ۲۰۰۵ دیدگاه T-Weighted برای پردازش اطلاعات عصبی در P300 وابسته به BCI را بررسی کرده که در آن از دو سری دادگان BCI2005-II و BCI2003-IIb استفاده شده است. او توانست با استفاده از آنالیز مؤلفه‌های اصلی^۸ (PCA) و استخراج ویژگی با روش T-weighted، روی دادگان سال ۲۰۰۳ به صحت ۱۰۰٪ و روی دادگان سال ۲۰۰۵ به صحت ۹۰٪ در تشخیص کاراکتر برسد.^[۱۱]

Sellers , Krusinski در تحقیقی دیگر در سال ۲۰۰۷ به بررسی اثر گسترش فضای ویژگی P300 روی عملکرد طبقه‌بندی کننده پرداختند و دادگان خود را از طریق ماتریس BCI استاندارد speller P300 و رعایت قوانین سیستم ۲۰۰۰ و با آزمایش روی ۷ فرد سالم به دست آورdenد. برای رسیدن به هدف فوق الذکر، در انتخاب ویژگی سعی شد تا علاوه بر ویژگی‌های به دست آمده از کانال‌های قسمت مرکزی مغز، از قسمت پسین هم کانال‌هایی برای به دست آوردن اطلاعات جدید اضافه شود. همچنین اثر انتخاب کانال ثبت EEG، مرجع کانال‌ها، بُعد داده‌ها و حداکثر تعداد ویژگی‌های یک مدل هم مورد بحث قرار گرفت و نتیجه نهایی که ذکر شده، آن است که با روش SWLDA و با استفاده از الکترود مرجع گوش، کانال‌های O7,PO7,PO8

بخش به شرح قسمت‌های مختلف این سیستم آشکارساز پرداخته می‌شود. قابل ذکر است که در این تحقیق، کلیه پردازش‌های مربوط به پیش‌پردازش، استخراج ویژگی و طبقه‌بندی سیگنال‌ها در نرم افزار MATLAB R2009a و روال انتخاب ویژگی با استفاده از نرم افزار SPSS انجام شده است.

۱-۳- پیش‌پردازش

قبل از مرحله استخراج ویژگی، لازم است تا یکسری پردازش‌های اولیه روی سیگنال‌ها اعمال شود تا برای مراحل بعدی آماده شوند. بدین منظور ابتدا یک فیلتر میان‌گذر ۰/۵ تا ۳۵ هرتز به سیگنال اعمال شد، زیرا عمدۀ مولفه‌های انرژی P300 در فرکانس‌های پایین است. پس از فیلتر کردن، نوبت به نرمالیزه کردن دادگان می‌رسد. با توجه به یکسان نبودن شرایط ثبت در کانال‌های مختلف و تفاوتات کیفیت و قدرت سیگنال ثبت شده در بعضی کانال‌ها، سیگنال فیلتر شده در هر کانال، به بازه [۱، ۱۰] نرمالیزه شد. به منظور سهولت در انجام کار و جلوگیری از بروز اشتباہ، سیگنال‌ها به قطعاتی که از زمان روشن شدن یک سطر یا یک ستون آغاز می‌شوند و به مدت یک ثانیه (معادل ۲۴۰ نمونه) ادامه دارند، تقسیم می‌شوند. همچنین همان طور که گفته شد ثبت دادگان طبق سیستم ۰-۱۰ و به صورت ۶۴ کاناله صورت گرفته است، اما از آنجا که این تعداد کانال بسیار زیاد است و حجم و پیچیدگی محاسبات را زیاد می‌کند؛ لازم است که در ابتدای کار کانال‌های مناسب را انتخاب کرد. با بررسی قدرت موج P300 به دست آمده از متوسط سیگنال‌ها، این نکته مشخص می‌گردد که بیشترین فعالیت P300 در مرکز سر صورت می‌گیرد و تقریباً در هر دو سمت چپ و راست متقارن است[۱۴]. با توجه به این مسئله و با استفاده از کانال‌های مناسب مشترک برای هر دو سوزه A و B، که توسط نفر دوم مسابقات BCI معرفی شده بود، در این مقاله در مرحله استخراج ویژگی‌های قطعه‌بندی هوشمند از هفت کانال Po7، Po8، Fz، C3، Cz، C4، Pz، استفاده شد[۱۵]، اما در روش الگوهای مکانی مشترک (با توجه به خاصیت

تفکیک کاراکترهایش) به عنوان مورد هدف توسط آزمایشگر تعیین شده است که در بالای جدول نمایش داده می‌شود.

| SEND | | | | | | |
|------|---|---|---|---|---|--|
| A | B | C | D | E | F | |
| G | H | I | J | K | L | |
| M | N | O | P | Q | R | |
| S | T | U | V | W | X | |
| Y | Z | 1 | 2 | 3 | 4 | |
| 5 | 6 | 7 | 8 | 9 | _ | |

شکل (۱): ماتریس تحریک برای ثبت دادگان[۹]

در ابتدای ظاهر شدن جدول، تمام حروف به رنگ خاکستری دریک پس زمینه سیاه نمایان می‌شوند. سپس به طور تصادفی یک سطر یا ستون روشن شده و به رنگ سفید در می‌آید. این سطر یا ستون به مدت ۱۰۰ میلی ثانیه تمام وضعیت روشن باقی می‌ماند و سپس ۷۵ میلی ثانیه تمام سطر و ستون‌ها خاموش می‌مانند تا آنکه سطر یا ستون بعدی به طور تصادفی روشن شود، به نحوی که قبل از روشن شدن سطر یا ستون تکراری تمام سطراها و ستون‌ها یک بار روشن شده باشند. بدین ترتیب برای یک دور کامل از آزمایش، ۱۲ تحریک اتفاق می‌افتد که فقط دو مورد حاوی کاراکتر هدف و در نتیجه مؤلفه P300 هستند. این آزمایشات برای هر کاراکتر ۱۵ مرتبه تکرار شده است، لذا برای هر کاراکتر ۳۰ سیگنال حاوی P300 و ۱۵ سیگنال فاقد آن موجود می‌باشد. این سیگنال‌ها از یک فیلتر میان‌گذر ۰/۱ تا ۶۰ هرتز عبورداده شده و با نرخ ۲۴۰ هرتز نمونه-برداری شده‌اند. همچنین از استاندارد ۲۰-۱۰، ۶۴ کاناله برای الکتروودگذاری در ثبت EEG استفاده شده است.

۳- روش کار

همانطور که اشاره شد، سیستم مورد استفاده در این مقاله برای آشکارسازی مؤلفه P300 مبتنی بر روش بازناسی آماری الگو است. این سیستم‌ها عموماً از دو بلوک اصلی استخراج ویژگی و طبقه‌بندی تشکیل شده‌اند که می‌تواند بلوک‌های جانبی دیگری همچون پیش‌پردازش یا انتخاب ویژگی نیز به آن اضافه گردد. با این مقدمه، در این

اختلاف بین دو کلاس را واضح‌تر کند و درجه تفکیک بین دو کلاس را بالا ببرد. برای پیاده‌سازی این روش قطعه‌بندی، الگوریتم جایگزینی تکراری محلی^{۱۲} (LIR) به کار گرفته شد.

در این الگوریتم، پس از یک قطعه‌بندی اولیه، مکان جدید یک نقطه شکست به صورت بهینه بین دو نقطه شکست همسایه‌اش انتخاب می‌شود و به این ترتیب، نقاط شکست به تدریج به سمت محل بهتر حرکت می‌کنند تا به نقطه بهینه محلی برسند.^{۱۳} مراحل اجرای این الگوریتم را می‌توان در چهار گام زیر خلاصه کرد:

- ۱- انتخاب اولیه نقاط شکست به صورت سلسله مراتبی (با استفاده از نمونه برداری یکنواخت یا به صورت تصادفی یا با استفاده از روش‌هایی مثل روش از بالا به پایین).
- ۲- انتخاب نقطه شکست ($1 \leq i \leq k$) به صورت تصادفی یا ترتیبی و حذف این نقطه و اتصال دو قطعه متولی که در c_i به یکدیگر می‌رسیدند:

۳- یافتن یک مکان بهینه (براساس معیار بهینگی موردنظر) برای نقطه شکست جدید (c'_i) قطعه مرکب ساخته شده در گام دوم و جایگزین کردن c'_i به جای c_i .

۴- تکرار گام‌های ۲ و ۳ تا رسیدن به معیار توقف. در اینجا ذکر دو نکته لازم است؛ اول آنکه می‌توان نشان داد که این الگوریتم در حلقه تکرار گیر نمی‌کند و پس از چند بار اجرا متوقف می‌شود.^{۱۴} اما از طرفی تصمیمی نیست که نهایتاً به حل بهینه منجر شود، زیرا این روش نقطه بهینه محلی را انتخاب می‌کند، نه نقطه بهینه مطلق را.

نکته دیگر آنکه در هر مرحله لازم نیست تمامی نقاط شکست بررسی شوند و اگر سه قطعه مجاور

$$s\left(\begin{matrix} c_{i-2} \\ 1, c_{i-1} \end{matrix}\right), s(c_{i-1} + 1, c_i), s(c_i + 1, c_{i+1})$$

در یک مرحله تغییری نکردند، دیگر لازم نیست که نقاط c_{i-1} در مرحله بعد بررسی شوند. با توجه به این مسئله، تعداد بررسی‌های لازم در هر مرحله نهایتاً سه برابر تعداد نقاط شکست تغییر یافته در مرحله قبل است. زمان کلی محاسبات نیز به نحوه تنظیمات اولیه و نوع دادگان مورد بررسی وابسته است.

این روش که در ادامه توضیح داده خواهد شد، کل ۶۴ کanal به کار گرفته شد.

آخرین مرحله پیش‌پردازش، میانگین‌گیری است. در بسیاری از تحقیقات، پیشنهاد می‌شود سیگنال‌های دارای کد تحریک یکسان در هر حرف با یکدیگر متوسط‌گیری شوند.^{۱۵} این امر سبب می‌شود الگوی P300 که در تمام ثبت‌ها دارای شکل یکسانی است، با همان قدرت باقی بماند و با توجه به مستقل بودن نویزها در ثبت‌های مختلف از یکدیگر قدرت نویز کاهش یابد.

۲-۳- استخراج ویژگی

پس از اعمال پیش‌پردازش، نوبت به استخراج ویژگی می‌رسد. در اینجا از دو روش قطعه‌بندی هوشمند و الگوهای مکانی مشترک استفاده شده است که در ادامه هر کدام از این روش‌ها شرح داده می‌شوند.

قطعه‌بندی^{۱۶} هوشمند

در سال‌های اخیر مسئله قطعه‌بندی سری‌های زمانی به صورت گسترشده و با روش‌های مختلفی مطالعه شده و تقریب سیگنال‌ها با استفاده از قطعات خطی هم از این دست است. هدف این مسائل، غالباً فشرده‌سازی دادگان، استخراج ویژگی یا فیلتر کردن و حذف نویز است. در کاربردهای مختلفی نظیر گرافیک‌های رایانه‌ای، نقشه کشی و بازشناسی الگو از این تکنیک کاهش حجم به منظور ساده‌سازی یا برای تحلیل کانتورها و خطوط مرزی استفاده می‌شود.^{۱۷}

در اینجا روشی برای قطعه‌بندی سیگنال ارائه می‌شود که در آن یک سیگنال به طول N ، با k قطعه خط مستقیم تقریب زده می‌شود و از آنجا که عموماً k بسیار کوچکتر از N است، این قطعه‌بندی در کاهش حجم محاسبات و حافظه لازم برای آن بسیار مؤثر است. این پروسه می‌تواند به عنوان یک مرحله استخراج ویژگی در سیستم بازشناسی الگو استفاده شود.

در این مقاله از یک روش قطعه‌بندی هوشمند استفاده شده است. ایده اولیه این طرح آن است که فرض شده یک کاهش نرخ نمونه برداری مؤثر بر روی دادگان می‌تواند

شکل (۲): کاهش نرخ نمونه برداری وفقی و تولید بردار ویژگی [۲۱]

ایده اصلی آن است که این بازه‌ها با تعلیم گرفتن از دادگان آموزش به گونه‌ای تعیین شوند که درجه تفکیک بین دو کلاس بیشینه شود. برای جدا کردن کلاس‌ها به معیاری از شباهت یا عدم شباهت نیاز است و در اینجا از معیار جدایپذیری فیشر^{۱۵} (FDC) استفاده شده است [۲۲]. از این معیار در تحلیل تفکیکی فیشر (FDA)^{۱۶} که یک روش تحلیل تفکیکی خطی است هم استفاده می‌شود. یک FDA روش کاهش بعد آموزش پذیر است که در آن نگاشتی خطی اعمال می‌شود که درجه تفکیک بین کلاس‌ها را بر اساس دادگان آموزش بیشینه می‌کند. در FDA بردار نگاشتی ساخته می‌شود که نسبت مریع تفاضل میانگین بین کلاس‌ها به مجموع واریانس بین کلاس‌ها را بیشینه می‌کند. برای رسیدن به این بردار ابتدا بردارهای میانگین را تعریف می‌کنیم:

$$m_0 = \frac{1}{N_0} \sum_{i:y_i=0} x_i, m_1 = \frac{1}{N_1} \sum_{i:y_i=1} x_i \quad (1)$$

که در آن N_0 و N_1 بیانگر تعداد دادگان آموزش برای دو کلاس و $\{0,1\} \in y_i$ بیانگر برچسب هر کلاس است. سپس دو نوع واریانس با نام‌های کوواریانس درون کلاسی^{۱۷} (W) و کوواریانس بین کلاسی (B)^{۱۸} تعریف می‌شود:

$$W = \sum_{l=0}^1 \sum_{i:y_i=l} (x_i - m_l)(x_i - m_l)^T \quad (2)$$

$$B = (m_0 - m_1)(m_0 - m_1)^T$$

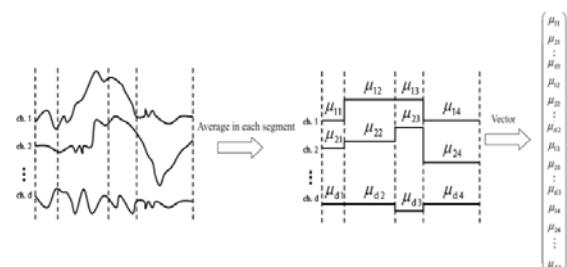
حال بردار نگاشت FDA توسط برداری که مقدار $J(a)$ را در رابطه زیر بیشینه کند، داده می‌شود:

$$J(a) = \frac{a^T B a}{a^T W a} \quad (3)$$

J(a) در رابطه فوق همان معیار جدایپذیری فیشر است. همان‌طور که پیش از این ذکر شد، هدف بیشینه کردن این معیار و در نتیجه بیشینه کردن تفکیک پذیری بین دو کلاس است. به همین منظور، با مشتق گیری از رابطه فوق بر حسب a و پس از ساده‌سازی خواهیم داشت:

یک معیار توقف طبیعی برای این الگوریتم آن است که زمانی الگوریتم متوقف شود که با هرگونه حرکت مجاز نقاط شکست، هزینه کلی قطعه‌بندی کمتر از میزان فعلی آن نشود. طبق این معیار LIR پس از تعداد محدودی اجرا متوقف می‌شود، زیرا در هر مرحله هزینه کم می‌شود و تعداد نقاط در دنباله هم محدود است. یک معیار ساده دیگر هم برای توقف الگوریتم می‌تواند محدود کردن تعداد تکرارهای الگوریتم باشد. الگوریتم‌های تکراری تصادفی می‌توانند تعداد دفعات کمی اجرا شوند تا احتمال گرفتار شدن‌شان در مینیمم محلی ضعیف شود.

برای آشکارسازی مؤلفه P300 از طریق بازناسی آماری الگو، به تعریف یک بردار ویژگی نیاز داریم. یکی از راههای رایج برای ساخت این بردار، متوالی کردن دادگان سیگنال EEG ثبت شده از کانال‌های مختلف است، ولی ساخت بردار ویژگی با تمامی نمونه‌های همه این کانال‌ها می‌تواند به ایجاد یک بردار ویژگی با بعد بسیار بالا منجر شود و با توجه به تعداد محدود دادگان، این امر ممکن است سیستم را به نفرین ابعاد^{۱۹} دچار سازد. برای اجتناب از این مشکل بسیاری از محققان از کاهش نرخ نمونه برداری برای کم کردن بعد بردار ویژگی استفاده کرده‌اند که در اغلب تحقیقات از یکی از دو روش حذف نمونه‌های بینایین^{۲۰} یا نمونه برداری یکنواخت استفاده شده است (در روش اول از هر k نمونه یکی انتخاب و بقیه حذف می‌شوند و در روش دوم از متوسط این k نمونه استفاده می‌شود) [۲۰، ۱۹، ۱۰]. ولی در اینجا از یک روش کاهش نرخ نمونه برداری وفقی آموزش پذیر استفاده شده و به این طریق صحت سیستم در تشخیص مؤلفه P300 افزایش یافته است. در این روش از قطعه‌بندی غیریکنواخت بازه‌ها که در شکل (۲) دیده می‌شود، استفاده شده است و از متوسط هر قطعه به عنوان نماینده آن قطعه در بردار ویژگی استفاده می‌شود [۲۱].



$$X_i(T) = \text{Make Vector}(S_i, T)$$

$$= \begin{pmatrix} \frac{1}{\tau_1 - \tau_0} \sum_{t=\tau_0+1}^{\tau_1} s_i(t) \\ \frac{1}{\tau_2 - \tau_1} \sum_{t=\tau_1+1}^{\tau_2} s_i(t) \\ \vdots \\ \frac{1}{\tau_k - \tau_{k-1}} \sum_{t=\tau_{k-1}+1}^{\tau_k} s_i(t) \end{pmatrix}^t \quad (8)$$

X_i به دست آمده توسط این تابع یک بردار $d \times k$ بعدی است و پس از اعمال این تابع به دادگان آموزش، مجموعه $\tilde{E}(T) = \{(X_i(T), y_i) | i = 1, \dots, N\}$ تبدیل می‌شود: E به \tilde{E} از روی دادگان E می‌شوند تا معیار جداپذیری فیشر در فضای جدید محاسبه شود که از آن به عنوان معیار جداپذیری فیشر استفاده می‌شود:

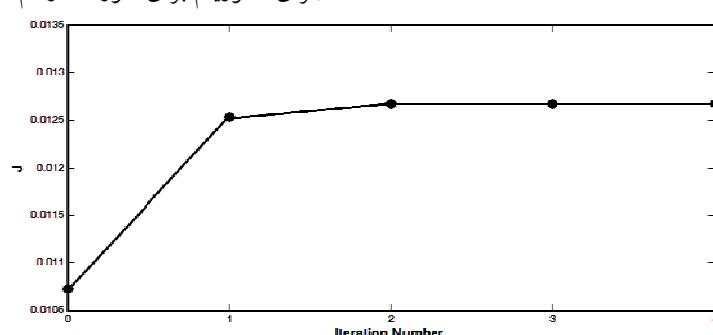
$$J(T) = (m_0(T) - m_1(T))^T W(T)^{-1} (m_0(T) - m_1(T)) \quad (9)$$

نهایتاً مسئله یافتن قطعاتی که درجه تفکیک بین کلاس‌ها را بیشینه کند، به مسئله یافتن \hat{T} بهینه تقلیل می‌یابد که آن را می‌توان در رابطه زیر خلاصه کرد:

$$\hat{T} = \text{argmax}_T J(T) = \text{argmax}_{\tau_0, \tau_1, \dots, \tau_k} J(T) \quad (10)$$

subject to $\tau_j \in N, \tau_j < \tau_{j+1}, \tau_0 = 0, \tau_k = n$

با استفاده از الگوریتم LIR توضیح داده شده و با توجه به آنکه هدف، بیشینه کردن میزان تفکیک بین دو کلاس است، الگوریتم زمانی متوقف می‌شود که در دو اجرای متوالی آن، مقدار معیار تفکیک پذیری (J) بیشتر نشود یا ثابت بماند. برای مثال، در شکل (۳) روند تغییرات J هنگام اجرای الگوریتم برای سوژه A رسم شده است.



شکل (۳): روند تغییرات معیار تفکیک پذیری دو کلاس (J) هنگام اجرای الگوریتم LIR برای سوژه A

$$Ba = \lambda Wa \quad \text{where: } \lambda = \frac{a^t Ba}{a^t Wa} \quad (4)$$

اگر W معکوس پذیر باشد، معادله مقادیر ویژه تعمیم یافته فوق را می‌توان به فرم معادله مقادیر ویژه استاندارد زیر نوشت:

$$W^{-1}Ba = \lambda a \quad (5)$$

و با توجه به رابطه فوق، می‌توان a را از رابطه زیر به دست آورد:

$$a \propto W^{-1}(m_0 - m_1) \quad (6)$$

با جای گذاری معادله (6) در معادله (۳) رابطه زیر حاصل می‌شود که از آن به عنوان معیار جداپذیری فیشر استفاده می‌شود.

$$J = (m_0 - m_1)^T W^{-1} (m_0 - m_1) \quad (7)$$

با توجه به مطالعه فوق، اگر $E = \{(S_i, y_i) | i = 1, \dots, N\}$ مجموعه دادگان آموزش باشد که در آن $y_i \in \{0, 1\}$ برحسب هر کلاس و $S_i \in \text{Bianker DADGAN}$ است و هر تک ثبت EEG شامل n نمونه باشد، S_i به $s_i(t) \in R^d$ که $S_i = \{s_i(1), s_i(2), \dots, s_i(n)\}$ صورت $s_i(t) \in R^d$ است، تعریف می‌شود و d هم تعداد کانال‌ها را مشخص می‌کند. اگر تعداد قطعات مدنظر برای قطعه‌بندی k باشد، نقاط شکست بین این قطعات به صورت $\tau_j \in N, \tau_j < \tau_{j+1}, \tau_0 = 0, \tau_k = n$ تعریف می‌شود. سپس تابعی با نام $\text{Make Vector}(S_i, T)$ تعریف می‌شود که به وسیله آن نرخ نمونه برداری در S_i کاهش یافته و به یک بردار تبدیل می‌شود:

بیشتر برای روش‌های بازشناسی الگو طراحی شده- در سال ۱۹۹۵ توسط Koles مطرح شد^[۲۳] و نخستین بار برای تجزیه مؤلفه‌های نوروفیزیولوژیک در کاربردی کلینیکی از الکتروانسفالوگرافی استفاده شد. روش الگوهای مکانی مشترک بر اساس قطری سازی همزمان دو ماتریس متقاضان حقیقی (که توسط Fukunaga ارائه شدند^[۲۴]) کار می‌کند. قطری سازی همزمان اجازه تجزیه سیگنال EEG خام به دو الگوی مجزا از دو کلاس را می‌دهد که در این دو کلاس به صورت همزمان، واریانس یکی از کلاس‌ها بیشینه و واریانس دیگری کمینه شده است. در این صورت، اگر تنها از فیلترهای با قابلیت تفکیک بیشتر استفاده شود، ابعاد داده هم کاهش می‌یابد و عملکرد طبقه‌بندي کننده نیز بهتر می‌شود.

این روش به صورت موفقیت آمیزی در تحقیقات BCI برای استخراج و افزایش ERD/ERS و در مسائل تفکیک تصورات حرکتی^{۲۰} به کار رفته است، ولی کاربرد روش CSP در آشکارسازی ERP و P300 بسیار کم بوده و در تحقیقات کمی از آن استفاده شده است [۲۵، ۲۶، ۲۷]. یکی از روش‌های استخراج ویژگی مورد استفاده در این مقاله، روش الگوهای مکانی مشترک است که در اینجا به بیان مفهوم آن می‌پردازیم^[۲۸]:

فرض کنید X_t و X_{nt} هر کدام ماتریسی $N \times T$ باشند که N تعداد کanal‌های ثبت و T تعداد نمونه‌های زمانی از هر کanal باشد و این دو ماتریس به ترتیب مربوط به دادگان هدف (حاوی مؤلفه P300) و دادگان غیرهدف (فاقد P300) هستند. روش CSP بر اساس تجزیه مؤلفه اصلی ماتریس کوواریانس R است که این ماتریس از مجموع ماتریس کوواریانس‌های دادگان هدف (\bar{R}_t) و غیر هدف (\bar{R}_{nt}) به دست می‌آید^[۲۸]. تجزیه این ماتریس در رابطه (۱۱) نشان داده شده است.

$$\bar{R} = \bar{R}_t + \bar{R}_{nt} = A\lambda A'$$
 (۱۱)

در رابطه (۱۱)، A ماتریس متعامد بردارهای ویژه \bar{R} و \bar{A} ماتریس قطری مقادیر ویژه \bar{R} است. اکنون با استفاده از ماتریس سفیدکنندگی W، ماتریس کوواریانس \bar{R} به ماتریس همانی I تبدیل می‌شود.

پس از همگرا شدن الگوریتم، بردار ویژگی حاصل می-شود. در این بردار، تعداد ویژگی‌ها به ازای هر کanal برابر تعداد قطعات (k) است که هر ویژگی به صورت میانگین مقادیر دامنه نمونه‌ها در قطعه مربوطه تعریف می‌شود (مطابق شکل (۲)). بردار ویژگی برای هر کاراکتر از متوالی کردن ویژگی‌های کanal‌های هفتگانه پشت سر هم به دست می‌آید؛ یعنی بعد بردار حاصل برای هر کاراکتر برابر k می‌شود.

مسئله مهم دیگر در مورد این الگوریتم، انتخاب k مناسب است، زیرا اگر k بیش از حد کوچک باشد، ممکن است تقریب حاصل از سیگنال، تقریب مناسبی نباشد و بخشی از اطلاعات مهم سیگنال از دست بروند و از طرفی اگر هم k بیش از اندازه بزرگ شود، دیگر به خواسته اصلی خود که کم کردن حجم دادگان و جلوگیری از مشکل نفرین ابعاد است، نمی‌رسیم. بر این اساس، با آزمودن چند مقدار متوالی برای k و محاسبه دقت سیستم با استفاده از طبقه-بندي کننده SWLDA^{۱۹} در هر آزمون، نهایتاً k مناسب برای دادگان استفاده شده در اینجا، که صحت در آن بیش از k‌های قبلی و بعدی بود (k=10)، انتخاب شد. نتایج بررسی k‌های مختلف در جدول (۱) آمده است.

جدول (۱): بررسی اثر تغییرات تعداد قطعات روی صحت

طبقه‌بندي کننده

| تعداد قطعات (k) | درصد صحت طبقه‌بندي |
|-----------------|--------------------|
| ۷/۹۲/۸ | ۸ |
| ۷/۹۴/۹ | ۹ |
| ۷/۹۴/۶ | ۱۰ |
| ۷/۹۴/۵ | ۱۱ |
| ۷/۹۴ | ۱۲ |

الگوهای مکانی مشترک (CSP)

کارایی فیلتر کردن مکانی برای بهبود رزولوشن مکانی و نسبت سیگنال به نویز در سیگنال EEG قبلاً ثابت شده است[۲۳، ۲۴]. برخی از انواع فیلترهای مکانی مبتنی بر روش‌های EEG referencing هستند. این فیلترها به عنوان فیلترهای مکانی بالاگذرنی عمل می‌کنند که فعالیت محلی را تقویت و فعالیت توزیع شده را ضعیف می‌کنند. یک ایده متفاوت، فیلترهای مکانی با نام الگوهای مکانی مشترک- که

کاهش بعد هم صورت می‌گیرد و به جای استفاده از تعداد زیادی کanal، در فضایی جدید، کanal‌های جایگزین کمتری با قابلیت تفکیک بیشتر دو کلاس فراهم می‌شود. بنابراین برای استخراج ویژگی‌ها با این روش، از کلیه سیگنال‌های ثبت شده در ۶۴ کanal استفاده شد که خود سبب افزایش حجم دادگان می‌شد. برای مقابله با این مسئله، پس از اعمال یک فیلتر آنتی الیاسینگ، از کاهش نرخ نمونه برداری استفاده کرد، تعداد دادگان در هر قطعه یک ثانیه‌ای از ۲۴۰ نمونه به ۲۴ نمونه کاهش داده شد. پس از آن با اعمال CSP، بردارها و مقادیر ویژه هر کلاس طبق روابط (۱۷) و (۱۸) محاسبه شدند. سپس از دو بردار ویژه ابتدایی و دو بردار ویژه انتهایی ماتریس بردارهای ویژه برای ساخت ماتریس فیلترهای مکانی استفاده شد و ماتریس H با اندازه $N \times 4$ به دست آمد. برای استخراج ویژگی‌های CSP، با توجه به تحقیقات قبلی [۲۸] دو دسته ویژگی بیشتر مطرح بود: دسته اول ویژگی‌ها در واقع همان دادگان زمانی هستند که توسط فیلتر مکانی تهیه شده فیلتر شده‌اند؛ به صورتی که هر داده زمانی $N \times T$ بعدی - که N تعداد کanal‌های ثبت (۶۴ تا) و T تعداد نمونه‌های زمانی از هر کanal است به داده فیلتر شده $T \times 4$ بعدی تبدیل می‌شود، دسته دوم ویژگی‌هایی مبتنی بر واریانس هستند که بیشتر در کاربردهای تصورات حرکتی سیستم‌های BCI کاربرد دارند. این ویژگی‌ها در بحث‌های تصورات حرکتی معمولاً به صورت نسبتی واریانس یک داده فیلتر شده به مجموع واریانس‌های کل دادگان فیلتر شده تعريف می‌شوند. برای ساخت این دسته ویژگی‌ها طبق رابطه زیر، برای هر داده زمانی چهار ویژگی جدید به دست می‌آید:

$$f_k = \log \left[\frac{\text{var}(H_k S)}{\sum_{i=1}^4 \text{var}(H_i S)} \right] \quad (21)$$

که در آن S یک داده زمانی $T \times N$ بعدی و H_k سطر k از ماتریس H در رابطه (۲۰) (منتظر با یک بردار ویژه) است. به این ترتیب، بردار ویژه حاصل از CSP هم با متوالی کردن این دو دسته ویژگی به دست می‌آید.

$$W = \lambda^{-\frac{1}{2}} A' \quad (12)$$

$$S = W \bar{R} W' = I \quad (13)$$

سپس با استفاده از تبدیل سفید کردن برای هر کلاس به دست می‌آید:

$$\begin{aligned} S_t &= W \bar{R}_t W' \\ S_{nt} &= W \bar{R}_{nt} W' \end{aligned} \quad (14)$$

با استفاده از سه رابطه اخیر به دست می‌آید:

$$S_t + S_{nt} = I \quad (15)$$

با اعمال آنالیز مؤلفه‌های اصلی به روابط (۱۴) داریم:

$$S_t = A_t \lambda_t A_t' \quad S_{nt} = A_{nt} \lambda_{nt} A_{nt}' \quad (16)$$

و از (۱۵) و (۱۶) نتیجه می‌شود:

$$A_t = A_{nt} \quad (17)$$

$$\lambda_t = I - \lambda_{nt} \quad (18)$$

با توجه به روابط فوق دیده می‌شود که هر دو کلاس بردارهای ویژه یکسان دارند و ترتیب صعود و نزول مقادیر ویژه آنها برعکس یکدیگر است. به این ترتیب، یک تبدیل بهیمه کننده به دست می‌آید که می‌تواند حجم محاسبات را کاهش دهد؛ زیرا با این وضعیت اولین و آخرین سطرهای ماتریس بردارهای ویژه بیشترین اهمیت در تفکیک بین دو کلاس را دارد و پس از آنها دومین سطر و سطر ماقبل آخر و به همین منوال تا آخر. اگر A_t و A_{nt} به عنوان اولین و آخرین بردارهای ویژه با λ_t و λ_{nt} تعریف شوند، فیلترهای مکانی به صورت زیر طراحی می‌شوند:

$$\begin{aligned} H_t &= A_t' W \\ H_{nt} &= A_{nt}' W \end{aligned} \quad (19)$$

و دادگان فیلتر شده به وسیله این فیلترها از رابطه (۲۰) به دست می‌آیند؛ که در آن H ماتریس یا برداری از فیلترهای منتخب است.

$$Y = H X \quad (20)$$

همان طور که روابط فوق نشان داد، الگوهای مکانی مشترک یک روش استخراج ویژگی است که ضمن آن

ویژگی‌ای که معیار ورود به سیستم را برآورده کند، به مدل اضافه می‌شود. پس از اضافه شدن هر ورودی جدید به مدل، یک روند بازگشتی گام به گام پسرو برای حذف ویژگی‌هایی که کمترین اهمیت را دارند، به کار می‌رود. این پروسه تا زمانی که مدل شامل تعداد ویژگی‌های از پیش تعیین شده بشود، یا تا زمانی که هیچ ویژگی اضافه‌ای نمانده باشد که معیار خروج / ورود را برآورده کند، ادامه می‌یابد.

۴- نتایج

در این بخش نتایج کمی به دست آمده در قسمت‌های مختلف، بیان شده، تحلیل‌های حاصل از آنها ارائه خواهد شد.

۱- نتایج ارزیابی تکی ویژگی‌ها با استفاده از معیار t

برای بررسی ویژگی‌های مختلف و میزان تغییرات آنها در دو گروه مورد بررسی (هدف و غیرهدف)، در نخستین گام آزمون t-test برای تک تک ویژگی‌ها اجرا شد. متغیرهای مورد بررسی در این ارزیابی، ویژگی‌های استخراج شده از تک ثبت‌ها بودند و کلاس‌های مورد مقایسه، دو گروه حاوی P300 و فاقد P300 (هدف و غیرهدف) بودند.

دسته ویژگی قطعه‌بندی هوشمند، شامل ۷۰ ویژگی است به طوری که برای هر کanal ۱۰ ویژگی استخراج شده است. برای نمایش گویاتر نتایج، در شکل (۴) نمودار ستونی قدرمطلق t-value برای ویژگی‌های هر کanal تصویر شده است.

نتایج شکل (۴) نشان می‌دهد که در ارزیابی ویژگی‌های قطعه‌بندی هوشمند به صورت تک تک و با آزمون t-test در اغلب کانال‌ها ویژگی‌های ۴، ۳ و ۵ جزو ویژگی‌های برتر بوده‌اند. از طرفی، با توجه به مرزهای حاصل از قطعه‌بندی، مشخص می‌شود که ویژگی‌های ۴، ۳ و ۵ مربوط به بازه زمانی ۰۰۰ تا ۵۰۸ میلی‌ثانیه (محدوده رخداد مؤلفه P300) هستند.

همچنین، با بررسی الگوریتم LIR پیاده‌سازی شده، مشخص شد که مرزهای ده قطعه حاصل بر حسب نمونه

۳-۳- ابزارهای ارزیابی ویژگی

پس از محاسبه ویژگی‌های مختلف، نوبت به ارزیابی ویژگی‌ها می‌رسد. ارزیابی ویژگی‌ها در هر دو حالت تکی و گروهی قابل بررسی است. بدین منظور، ابتدا با استفاده از آزمون آماری t-test تک تک ویژگی‌ها ارزیابی شدند تا مشخص شود که در هر دسته ویژگی کدام ویژگی‌ها اطلاعات بیشتر و مفیدتری از سیگنال را دارا هستند. در قدم بعدی یک بار از طبقه‌بندی کننده LDA برای بررسی هر دسته ویژگی استفاده شد تا مشخص شود که کدام دسته ویژگی توانایی بیشتری در تفکیک دو کلاس دارد. یک بار هم از طبقه‌بندی کننده SWLDA استفاده شد. در این روش، ابتدا هر دسته ویژگی با استفاده از تحلیل تفکیکی گام به گام و با معیار Wilk's Lambda تحلیل و ویژگی‌های منتخب آن مشخص شد و سپس کار طبقه‌بندی با LDA صورت پذیرفت.

۳-۴- طبقه‌بندی

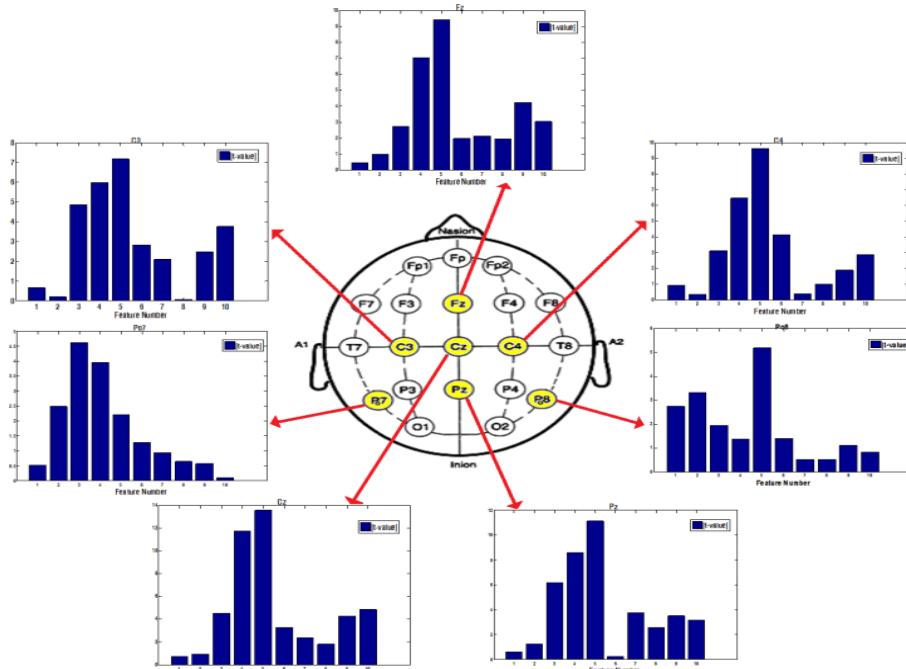
هدف نهایی در هر مسأله شناسایی الگو، تفکیک مجموعه‌ای از نمونه‌ها به دو یا چند کلاس مختلف است. در اینجا هدف نهایی، تفکیک سیگنال‌ها به دو گروه حاوی P300 و فاقد P300 است. در این مقاله، از طبقه‌بندی کننده‌های SWLDA و LDA (که در کارهای قبلی هم نتایج خوبی با استفاده از این طبقه‌بندی کننده‌ها گزارش شده بود) [۲۹] استفاده شد.

LDA ساده‌ترین و پرکاربردترین طبقه‌بندی کننده آماری است [۲۹]. این طبقه‌بندی کننده در فرم استانداردش یک طبقه‌بندی کننده باینری است که با اعمال تخمین^{۲۱} MAP و با فرض گوسی بودن تابع توزیع احتمال شرطی ویژگی‌ها در فضای ویژگی و همچنین تساوی ماتریس‌های کوواریانس کلاس‌ها محاسبه می‌شود.

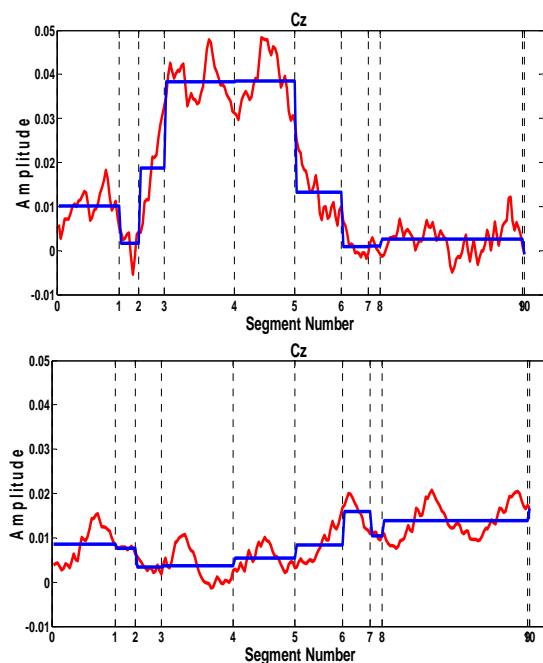
طبقه‌بندی کننده SWLDA هم در واقع همان LDA است که قبل از انجام عملیات طبقه‌بندی از یک روش پیش‌رو-پسرو برای انتخاب ویژگی استفاده می‌کند. در شروع هیچ ویژگی‌ای برای مدل در نظر گرفته نمی‌شود و

با توجه به محل قرار گرفتن این مرزها، مشخص است که در قسمت‌هایی که تفاوت شکل موج دو سیگنال هدف و غیر هدف بیشتر بوده، تعداد قطعه بیشتری تعریف شده است، اما در قسمت‌هایی که این تفاوت کمتر است، قطعات کمتر با طول بیشتر لحاظ شده‌اند.

به صورت ۰، ۳۲، ۴۲، ۵۵، ۹۱، ۱۲۲، ۱۴۶، ۱۶۰، ۱۶۶، ۲۲۹ یا بر حسب زمان به صورت ۰، ۱۳۳، ۲۰۰، ۲۲۹ و ۳۷۹، ۵۰۸، ۶۰۸، ۶۶۷، ۶۹۲ و ۹۹۶ میلی‌ثانیه بوده است. در شکل (۵) نمونه‌ای از متوسط سیگنال‌های هدف و غیرهدف، قبل و پس از قطعه‌بندی هوشمند دیده می‌شود.



شکل (۴): مقادیر $|t\text{-value}|$ برای ۱۰ ویژگی قطعه‌بندی هوشمند مربوط به هر یک از هفت کانال انتخابی

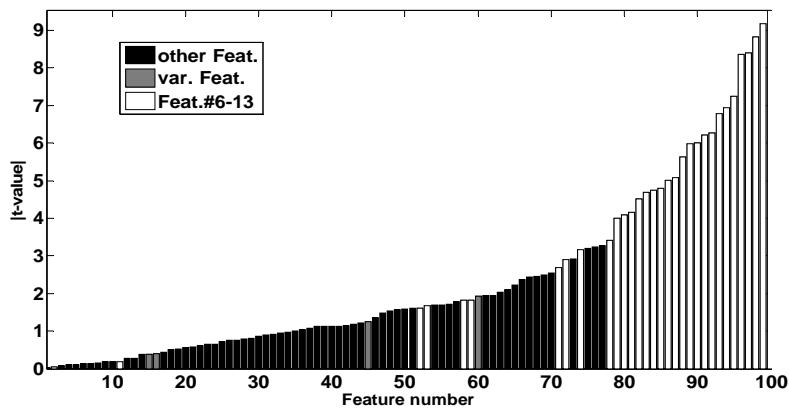


شکل (۵): بالا: متوسط کلیه سیگنال‌های هدف قبل و پس از اعمال قطعه‌بندی هوشمند در کانال Cz، پایین: متوسط کلیه سیگنال‌های غیر هدف قبل و پس از اعمال قطعه‌بندی هوشمند در کانال Cz

دوم ویژگی‌های مبتنی بر واریانس، که طبق توضیحات قبلی برای هر ثبت، $4 \times 24 = 96$ ویژگی نوع اول و چهار ویژگی نوع دوم تعریف شد و به این طریق دسته ویژگی حاصل از CSP شامل ۱۰۰ ویژگی شد. در ارزیابی ویژگی‌های الگوی مکانی مشترک توسط آزمون t-test در سه کanal از چهار کanal مورد استفاده در فضای CSP، ویژگی‌های متعلق به بازه زمانی ۵۴۲-۲۵۰ میلی‌ثانیه (ویژگی‌های ۶ تا ۱۳ هر کanal) ویژگی‌های برتر بوده‌اند که تشابه این محدوده زمانی در هر دو دسته ویژگی قطعه‌بندی هوشمند و الگوهای مکانی مشترک، مؤید این مطلب است که در هر دو فضای دادگان خام و فضای CSP، ویژگی‌های دو کلام هدف و غیرهدف در بازه زمانی رخداد P300 تفاوت آشکاری با یکدیگر دارند و این بازه، بازه مناسبی برای استخراج ویژگی‌های مؤثر و مفید در آشکارسازی P300 است. این ویژگی‌ها در شکل (۶) با رنگ سفید مشخص شده‌اند و به وضوح مشخص است که تجمع آنها بیشتر در انتهای نمودار و مقادیر بیشتر |t-value| است.

مثالاً در محدوده ۱۳۳ تا ۶۹۱/۵ میلی ثانیه، که طبق تعاریف فیزیولوژیک سیگنال ERP، محل رخداد مؤلفه‌هایی از قبیل N100، P300 و N400 (مؤلفه‌هایی که هنگام اعمال یک تحریک هدف رخ می‌دهند) است، هفت قطعه تعریف شده، ولی در محدوده انتهایی سیگنال (۶۹۲ تا ۹۹۵ میلی ثانیه) تنها یک قطعه برای نشان دادن سیگنال به کار رفته است. به این ترتیب، با استفاده از این روش قطعه‌بندی هوشمند، می‌توان بدون نگرانی از مشکلاتی مانند تعداد زیاد نمونه‌ها و بالا رفتن بعد بردار ویژگی، از مزایا و خواص مطلوب نمونه‌های زمانی سیگنال استفاده و قسمت‌های مهم سیگنال را بازتر نمود. در شکل (۵) هم این مسأله به شکل واضح‌تر بر روی دو سیگنال هدف و غیر هدف و نتیجه اعمال قطعه‌بندی بر روی آنها نشان داده شده است.

شکل (۶) مقادیر قدر مطلق t-value را به صورت صعودی برای دسته ویژگی CSP نشان می‌دهد. همان طور که در بخش ۲-۳ ذکر شد، این دسته ویژگی شامل دو نوع ویژگی است. نوع اول ویژگی‌های حاصل از فیلتر کردن داده‌ها با فیلتر مکانی به دست آمده با روش CSP و نوع



شکل (۶): مقادیر |t-value| برای دسته ویژگی الگوهای مکانی مشترک

اصلی توان‌های باند α و β هستند، این نوع ویژگی‌ها، ویژگی‌های مناسبی هستند، ولی در بحث آشکارسازی P300 که مهمترین ویژگی‌ها، ویژگی‌های شکلی-زمانی هستند، نه واریانس سیگنال، بهتر است که از خود دادگان فیلتر شده به وسیله فیلترهای مکانی به عنوان ویژگی استفاده شود.

در مورد این دسته ویژگی، ذکر این نکته هم مفید به نظر می‌رسد که ویژگی‌های مبتنی بر واریانس (که در شکل (۶) با رنگ خاکستری مشخص شده‌اند)، ویژگی‌های مطلوبی نبوده‌اند. البته، قبلاً هم ذکر شد که این ویژگی‌ها بیشتر در سیستم‌های BCI با کاربرد تصورات حرکتی استفاده می‌شوند. برای چنین سیستم‌هایی که در آنها ویژگی‌های

است. ابتدا طبقه‌بندي کننده خطی LDA بر هر دسته ویژگی اعمال و دقت با روش LOO^{۲۳} محاسبه شده است. در جدول (۲) این نتایج برای دو سوژه A و B و میانگین آن دو آورده شده است. بر اساس این نتایج، برای هر دو سوژه، قطعه‌بندي هوشمند سیگنانل به روش LIR بهترین کارایی را داشته است.

۴-۲- ارزیابی گروهی ویژگی‌ها

معیار دوم برای ارزیابی دسته ویژگی‌ها، مقایسه درصد صحت تفکیک آنها با یک طبقه‌بندي کننده است. در اینجا از دو طبقه‌بندي کننده SWLDA و LDA استفاده شده

جدول (۲): نتایج ارزیابی گروهی ویژگی‌ها با استفاده از صحت طبقه‌بندي کننده LDA

| درصد صحت نوع ویژگی | بعد بردار ویژگی | سوژه | هدف | غیرهدف | میانگین | میانگین A و B |
|--------------------|-----------------|-------|-------|--------|---------|---------------|
| ۷۰ | A | %۹۰ | %۹۴/۸ | %۹۴ | %۹۵/۰۵ | |
| | B | %۹۰/۵ | %۹۷/۲ | %۹۶/۱ | | |
| ۱۰۰ | A | %۷۷/۱ | %۸۶/۶ | %۸۵ | %۸۲/۴۵ | |
| | B | %۷۲/۴ | %۸۱/۴ | %۷۹/۹ | | |

ویژگی‌های ۹ تا ۵ (مریبوط به بازه ۲۰۸-۳۷۵ میلی‌ثانیه) انتخاب شده‌اند. بنابراین، هر دو روش t-test و تحلیل تفکیکی گام به گام، بیانگر اهمیت بازه رخداد مؤلفه P300 هستند.

در مورد میزان صحت حاصل توسط طبقه‌بندي کننده SWLDA هم در جدول (۳) بعد بردار ویژگی و درصد صحت برای هر دسته ویژگی و برای هر کدام از دو سوژه و به صورت میانگین آمده است.

در مرتبه دوم، روش تحلیل تفکیکی گام به گام به کار گرفته شد. با استفاده از این روش، ابتدا در هر دسته ویژگی‌های برتر انتخاب شدن و سپس با طبقه‌بندي کننده SWLDA درصد صحت هر دسته محاسبه شد.

با اعمال این روش انتخاب ویژگی به دسته ویژگی اول، از میان ۷۰ ویژگی قطعه‌بندي هوشمند، ۲۰ ویژگی انتخاب شدن که در این میان هم بیشتر ویژگی‌ها در همان محدوده رخداد P300 قرار دارند. در مورد دسته ویژگی CSP هم از میان ۲۶ ویژگی منتخب این دسته، در اغلب کانال‌ها

جدول (۳): نتایج ارزیابی ویژگی‌ها با روش تحلیل تفکیکی گام به گام و صحت طبقه‌بندي کننده SWLDA

| درصد صحت نوع ویژگی | بعد بردار ویژگی | سوژه | هدف | غیرهدف | میانگین | میانگین A و B |
|--------------------|-----------------|-------|-------|--------|---------|---------------|
| ۲۰ | A | %۹۱/۲ | %۹۵/۳ | %۹۴/۶ | %۹۵/۲۵ | |
| | B | %۹۲/۹ | %۹۶/۵ | %۹۵/۹ | | |
| ۲۶ | A | %۸۲/۹ | %۸۷/۹ | %۸۷/۱ | %۸۳/۴ | |
| | B | %۷۶/۵ | %۸۰/۴ | %۷۹/۷ | | |

برای سوژه A، طبقه‌بندي کننده LDA از ۷۰ ویژگی استفاده کرده، ولی در SWLDA تنها از ۲۰ ویژگی استفاده شده است که این مسئله پیچیدگیتابع تصمیم‌گیری را کمتر کرده، تعیین‌پذیری طبقه‌بندي کننده را افزایش می‌دهد. در واقع، برای

طبق جداول (۲) و (۳) دیده می‌شود که نتایج حاصل از این دو طبقه‌بندي کننده بسیار به هم نزدیک است، اما شاید بتوان حسن SWLDA را در تعداد ویژگی کمتر استفاده شده در آن دانست، مثلاً در مورد ویژگی‌های قطعه‌بندي هوشمند

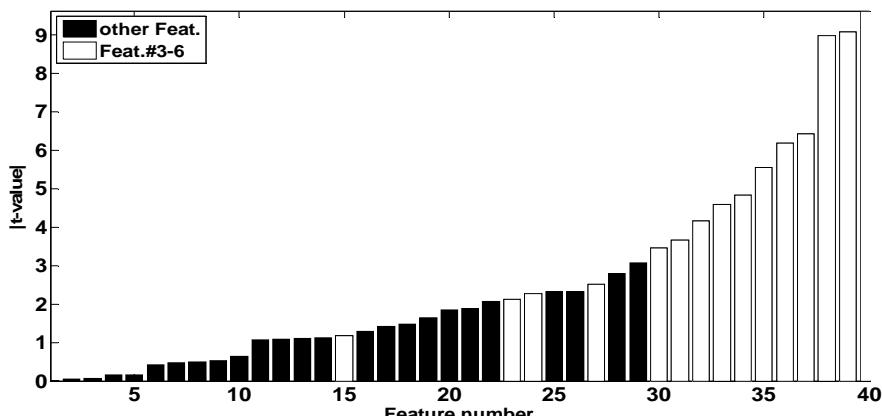
برای ساخت این دسته ویژگی، ابتدا CSP در نقش یک کاهش دهنده بعد ظاهر شده، دادگان را به فضایی جدید می‌برد که با وجود استفاده از تعداد کانال کمتر در آن فضا، قابلیت تفکیک زیادی از دست نمی‌رود و در عین حال، از مزیت کاهش تعداد کانال‌ها هم بهره برده می‌شود. سپس با استفاده از روش قطعه‌بندی هوشمند حجم دادگان را کاهش داده، دادگان بهینه‌تری را انتخاب می‌کنیم. با تکیه بر این ایده، این دسته ویژگی ترکیبی (با استفاده از همان پارامترهای به کار رفته در دو روش قطعه‌بندی هوشمند و CSP) ساخته شد؛ یعنی با استفاده از تعداد قطعه بهینه محاسبه شده ($k=10$)، این روش ترکیبی شامل ۴۰ ویژگی روی مجموع ۴ کانال منتخب فضایی جدید CSP است. نتایج ارزیابی این دسته ویژگی از دو دیدگاه تکی و گروهی در ادامه آمده است.

در ارزیابی تکی این ویژگی‌ها با آزمون t-test دیده می‌شود که در این دسته ویژگی نیز، مشابه دسته ویژگی اول و دوم، ویژگی‌های مربوط به بازه رخداد P300 (ویژگی‌های ۳ تا ۶ هر کانال) ویژگی‌های مناسب بوده‌اند و اختلاف آنها در دو کلاس مشهود بوده است. نمودار صعودی قدرمطلق مقادیر t-value برای ویژگی‌های ترکیبی در شکل (۷) (که ویژگی‌های ۳ تا ۶ هر کانال در آن با رنگ سفید مشخص شده است) مؤید همین مطلب است. نتایج ارزیابی گروهی این دسته ویژگی با دو طبقه‌بندی کننده LDA و SWLDA در جدول (۴) خلاصه شده است.

حل مشکل LDA روش SWLDA راه حلی ارائه داده است که با محدود کردن اندازه فضای ویژگی ورودی مشکل گستردگی ابعاد را برطرف کند. در این روش انتخاب ویژگی به صورت خودکار صورت می‌گیرد و جملات غیر مهم از مدل حذف می‌شوند. همچنین، می‌توان الگوریتم را به شیوه‌ای تنظیم کرد که سریعتر به همگرایی برسد

۴-۳- بررسی امکان تلفیق دو روش قطعه‌بندی هوشمند و الگوهای مکانی مشترک

با توجه به آنچه تا کنون درباره دو دسته ویژگی قطعه‌بندی هوشمند و الگوهای مکانی مشترک گفته شد، این ایده به ذهن می‌رسد که شاید ترکیب دو روش فوق به منظور ساخت یک دسته ویژگی ترکیبی مناسب باشد، زیرا همان طور که بیان شد، مزیت روش CSP در این است که در فضایی جدید، از تعداد کانال کمتری استفاده می‌کند و حسن قطعه‌بندی هوشمند هم در این است که با به کار گیری تعداد کانال زیادی استفاده شد که این امر حجم محاسبات را افزایش می‌دهد، بنابراین، می‌توان با ترکیب دو روش فوق، علاوه بر استفاده از مزایای دو روش، حجم محاسبات را هم کاهش داد. با این ایده دسته ویژگی ترکیبی CSP+LIR ساخته شد تا نتایج حاصل از آن نیز ارزیابی گردد.



شکل (۷): مقادیر |t-value| برای دسته ویژگی ترکیبی CSP+LIR

جدول(۴): نتایج ارزیابی گروهی دسته ویژگی ترکیبی

| درصد صحت طبقه‌بندی کننده | بعد بردار ویژگی | سوژه | هدف | غیرهدف | میانگین | میانگین A و B |
|--------------------------|-----------------|------|-------|--------|---------|---------------|
| LDA | ۴۰ | A | %۸۵/۳ | %۸۶/۲ | %۸۶/۱ | %۸۵/۲ |
| | ۴۰ | B | %۷۷/۸ | %۸۵/۴ | %۸۴/۳ | |
| SWLDA | ۱۸ | A | %۸۴/۱ | %۸۶/۲ | %۸۵/۹ | %۸۴/۰۵ |
| | ۱۷ | B | %۷۸/۸ | %۸۲/۸ | %۸۲/۲ | |

مکانی مشترک بود که هرچند در سایر حوزه‌های BCI پرکاربرد بوده، اما ویژگی‌های مستخرج از آن غالباً به گونه‌ای بوده‌اند (ویژگی‌های مبتنی بر واریانس) که در سیستم‌های مبتنی بر P300 توفیق چنانی نداشته‌اند. در این مقاله سعی شد تا با تعریف نوع دیگری از ویژگی‌های مبتنی بر CSP، کارایی هر دو نوع ویژگی در آشکارسازی P300 محک زده شود. در دسته ویژگی آخر هم از ترکیب دو روش استفاده شد تا از مزایای هر دو روش قبل بهره برده شود؛ یعنی هم با استفاده از CSP تعداد کانال‌ها را کاهش داد و هم با روش قطعه‌بندی هوشمند و کاهش نرخ نمونه‌برداری و فقی حجم محاسبات را کم کرد. بدین ترتیب، سه دسته ویژگی مختلف به دست آمد که با سه معیار-*t*-test، استفاده از درصد صحت طبقه‌بندی کننده LDA و استفاده از روش SWLDA به ارزیابی آنها پرداخته شد که نتایج به دست آمده نشان دهنده برتری روش قطعه‌بندی هوشمند نسبت به سایر روش‌ها بود؛ به طوری که با هر دو طبقه‌بندی کننده LDA و SWLDA بالاترین درصد صحت میانگین (۹۵٪/۲۵٪) توسط این دسته ویژگی به دست آمد. این درصد صحت بالا بیانگر قدرت و توانایی این دسته ویژگی و اهمیت نحوه تقسیم‌بندی سیگنال است. برتری روش قطعه‌بندی هوشمند نسبت به سایر روش‌های کاهش نرخ نمونه‌برداری در این است که این روش یک روش وفقی و آموزش‌پذیر است که سعی می‌کند مزه‌های قطعات را به نحوی تعیین کند که در عین زیاد کردن اختلاف بین دو کلاس، کمترین میزان اطلاعات از دست برود. همچنین، این روش کاهش نرخ نمونه‌برداری این امکان را فراهم می‌کند تا از قسمت‌هایی از سیگنال که اهمیت بیشتری دارد و حاوی اطلاعات بیشتری است، تعداد نمونه‌های بیشتری

در دسته ویژگی ترکیبی، فرضیه اولیه این بود که با بهره‌مندی از مزایای هر دو روش قبلی احتمالاً باید به نتایج برتری نسبت به هر دو روش به صورت مجزا، دست یافت، اما طبق جدول (۴) دیده شد، که هرچند نتایج روش ترکیبی از روش CSP بهتر شد، اما باز هم ضعیفتر از روش قطعه‌بندی است. این مسئله نشان می‌دهد که به کارگیری قطعه‌بندی در فضای خام دادگان و روی تعداد کانال بیشتر، کارایی بهتری نسبت به اعمال آن در فضای جدید با تعداد کانال کمتر دارد.

یک مسئله جانبی دیگر در مورد ویژگی‌های انتخاب شده به روش تحلیل تفکیکی گام به گام است. دیده می‌شود که در این دسته ویژگی هم غالباً ویژگی‌های مربوط به بازه رخداد P300 برگزیده شده‌اند، به طوری که در بین ۱۸ ویژگی انتخابی این دسته ویژگی، اکثر آنها (ویژگی‌های ۲ تا ۶ در هر کانال) در بازه زمانی ۶۹۳-۱۴۷ میلی‌ثانیه قرار می‌گیرند.

۵- نتیجه‌گیری

در این مطالعه، تلاش بر این بود تا با استفاده از یک سیستم مبتنی بر بازشناسی الگو به آشکارسازی P300 پرداخته شود و ضمن آن، کارایی سه روش مختلف استخراج ویژگی هم بررسی شود. دسته ویژگی اول، ویژگی‌های حاصل از قطعه‌بندی هوشمند سیگنال بودند. قطعه‌بندی، روش رایجی برای استخراج ویژگی در سیستم‌های بازشناسی الگوست، اما کاربرد آن در آشکارسازی مؤلفه P300 تا کنون بسیار کم بوده است. روش دوم هم استفاده از فیلتر کردن مکانی و الگوهای

- [2] J. Polich, "P300 in Clinical Applications," in *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, E. NiederMeyer and F. Lopes Da Silva, Eds., 4th ed. Baltimore, Maryland: Lippincott Williams and Wilkins, 2000, ch. 58, pp. 1073-1091.
- [3] J. P. Rosenfeld, "Event-Related Potentials in the Detection of Deception, Malingering, and False Memories," in *Handbook of Polygraph Testing*, M. Kleiner, Ed. New York: Academic Press, 2002, ch. 10, pp. 265-286.
- [4] L. A. Farwell and E. Donchin, "The truth will out: Interrogative polygraphy ('lie detection') with event-related brain potentials," *Psychophysiology*, vol. 28, no. 5, pp. 531-547, 1991.
- [5] و. ابوطالبی، "تجزیه و تحلیل مؤلفه های شناختی سیگنال الکتریکی مغز و کاربرد آن در دروغ سنجی،" پایان نامه دکترای مهندسی پزشکی - بیوالکتریک، دانشگاه صنعتی امیر کبیر، اردیبهشت ۱۳۸۵.
- [6] X. Neng, G. Xiaorong, H. Bo, M. Xiaobo, G. Shangkai, Y. Fusheng, "BCI competition 2003-data set IIb: enhancing P300 wave detection using ICA-based subspace projections for BCI applications," *IEEE Trans. on Biomed. Eng.*, vol.51, no.6, pp.1067-1072, June 2004.
- [7] S.A. Markazia, L.K. Stergioulas, A. Ramchurn, D. Bunce, "Latency Corrected Wavelet Filtering of the P300 Event-Related Potential in Young and Old Adults," In Proc. 3rd IEEE EMBS Conf., Neural Eng., CNE '07., pp.582-586, 2-5 May 2007.
- [8] M. Kaper, P. Meinicke, U. Grosskathofer, T. Lingner, H. Ritter, "BCI competition 2003-data set IIb: support vector machines for the P300 speller paradigm," *IEEE Trans. on Biomed. Eng.*, vol.51, no.6, pp.1073-1076, June 2004.
- [9] BCI Competition 2005. ida.first.fraunhofer.de/projects/bci/competition_n_ii
- [10] U. Hoffmann, G. Garcia, J.-M. Vesin, K. Diserens, T. Ebrahimi, "A Boosting Approach to P300 Detection with Application to Brain-Computer Interfaces," In Proc. 2nd IEEE EMBS Conf.on Neural Eng., 2005., pp.97-100, 16-19 March 2005.
- [11] L. Yang, Z. Zongtan, H. Dewen, D. Guohua, "T-weighted Approach for Neural Information Processing in P300 based Brain-Computer Interface," *Int. Conf. on Neural Net. and Brain, 2005. ICNN&B '05.*, vol.3, pp.1535-1539, 13-15 Oct. 2005.

ذخیره کرد و در عوض نمونه‌های حفظ شده از قسمت‌های کم اهمیت‌تر را کاهش داد. در مورد ویژگی‌های CSP، هرچند ویژگی‌هایی که از دادگان فیلتر شده به وسیله فیلتر مکانی تهیه شدند، به مراتب از ویژگی‌های مبتنی بر واریانس بهتر بودند، اما باز هم کارایی روش قطعه‌بندی هوشمند برتر از روش CSP است و این مسئله در نتایج حاصل از طبقه‌بندی کنده‌ها به وضوح مشخص است.

آخرین نکته، از نتایج t-test به دست می‌آید. طبق این نتایج در هر سه دسته ویژگی، ویژگی‌هایی که متعلق به محدوده زمانی رخداد P300 هستند، دارای |t-value| بالای هستند و قدرت تفکیک دو کلاس در آنها بالاست. این قضیه اهمیت بازه زمانی رخداد P300 را بیش از پیش نمایان می‌کند.

در مقام قیاس با سایر مطالعات انجام گرفته در این زمینه نیز باید گفت که نتایج حاصل از این تحقیق، نتایج خوب و قابل قبولی هستند؛ برای مثال، می‌توان به کارهای افرادی مانند Seller، Yang Liu و Salvaris اشاره کرد که با روش‌های مختلفی روی همین دادگان کار کرده‌اند و نتایج ضعیفتری به دست آورده‌اند. همان‌طور که در قسمت مقدمه هم ذکر شد؛ Yang Liu با روش T-weighted روی دادگان سال ۲۰۰۵ به صحت ۹۰٪ در تشخیص کاراکتر رسید و یا Krusinski و Sellers توانستند با حداقل ۶۰٪ ویژگی مدل، به صحت ۹۲/۵٪ روی این دادگان دست یابند. همچنین، بهترین صحت حاصل توسط Salvaris و همکارانش با استفاده از تبدیل موجک گستته و طبقه‌بندی کننده FLD، صحت میانگین ۹۵٪ بوده است، اما در این تحقیق ما توانستیم به صحت متوسط ۹۵/۲۵٪ بررسیم.

مراجع

- [1] س. رضانیا، "کمی سازی پتانسیل های وابسته به رخداد(ERP) در فرایند حافظه اپیزودیک بر پایه ویژگی های زمان-فرکانس جدید،" پایان نامه کارشناسی ارشد مهندسی پزشکی - بیوالکتریک، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، ۱۳۸۶-۸۷.

- spelling," *IEEE Int. Conf. on Machine Learning and Appl.*, pp.386-391, 2009.
- [21] Y. Sakamoto and M. Aono, "Supervised Adaptive Downsampling for P300-based Brain Computer Interface," *31st Int. Conf. on IEEE EMBS*, pp.567-570, September 2-6, 2009.
- [22] D. H. Foley, J. W. Sammon Jr., "An Optimal Set of Discriminant Vectors," *IEEE Trans. on Comp.*, Vol.24, No.3, pp.281-289, March 1975.
- [23] A. Soong and Z. Koles, "Principal-component localization of the sources of the background eeg," *IEEE Trans. on Biomed. Eng.*, vol. 42, no. 1, pp. 59-67, Jan. 1995.
- [24] K. Fukunaga, "Introduction to Statistical Pattern Recognition," *Second Edition. Morgan Kaufmann - Academic Press*, 1990.
- [25] D.J. Krusienski, E.W. Sellers, T.M. Vaughan, "Common Spatio-Temporal Patterns for the P300 Speller," *3rd Int. IEEE/EMBS Conf. on Neural Eng.*, 2007. CNE '07, vol., no., pp.421-424, 2-5 May 2007.
- [26] R. Li, A.Keil, J.C. Principe, "Single-trial P300 estimation with a spatiotemporal filtering method," *J. Neuroscience Methods*, vol.177 ,pp.488-496, 2009.
- [27] B. Rivet, H. Cecotti, R. Phlypo, O. Bertrand, E. Maby, J. Mattout, "EEG sensor selection by sparse spatial filering in P300 speller brain-computer interface," *32nd Int. IEEE EMBC Conf.*, pp. 5379-5382, Agu. 31- Sep. 4,2010.
- [28] G. Pires, U. Nunes, M. Castelo-Branco, "P300 spatial filtering and coherence-based channel selection," *4th IEEE EMBS Conf. on Neural Eng.*, NER '09., pp.311-314, April 29 2009-May 2 2009.
- [29] D. J. Krusienski, E.W. Sellers, F. ois Cabestaing, S. Bayoudh, D. J McFarland, T. M Vaughan and J. R Wolpaw, "A comparison of classification techniques for the P300 Speller," *J. Neural Eng.*,vol.3, pp.299-305, 2006.
- [12] D.J. Krusienski, E.W. Sellers, D.J. McFarland, T.M. Vaughan, J.R. Wolpaw, "Toward enhanced P300 speller performance," *J. Neuroscience Methods* , Vol. 167, pp.15-21, 2008.
- [13] M. Salvaris, F. Sepulveda, "Wavelets and ensemble of FLDS for P300 classification," *4th Int. IEEE/EMBS Conf. on Neural Eng.*, 2009. NER '09. vol., no., pp.339-342, April 29 2009-May 2 2009.
- [۱۴] ف. عطّری، "استخراج و پردازش سیگنال‌های EEG متاثر از بیوفیدبک جهت ارسال کاراکترهای مورد توجه شخص به کامپیوتر،" پایان نامه کارشناسی ارشد مهندسی پزشکی-بیوالکتریک، دانشگاه تهران، شهریور ۱۳۸۴
- [15] Z. Seyyedsalehi, A.M. Nasrabadi, V. Abootalebi, "Committee Machines and Quadratic B-spline Wavelet for the P300 Speller Paradigm," *IEEE/ACS Conf. on Comp. Sys. And Appl.*, pp.866-869, 2008.
- [16] T. Pavlidis, "Algorithm for Shape Analysis and Waveforms," *IEEE Trans. on Pattern Analysis and Machine Intelligence, PAMI-2(4)*: pp.301-312, 1980.
- [17] T. Rohlfing, D.B. Russakoff, and C.R. Maurer, "Performance-Based Classifier Combination in Atlas-Based Image Segmentation Using Expectation-Maximization Parameter Estimation," *IEEE Trans. on Med. Imag.*, vol.23, no.8, pp.983-994, Aug. 2004.
- [18] T. Pavlidis, "Waveform Segmentation Through Functional Approximation," *IEEE Trans. on Comp.*, C- 22(7): pp.689-697, 1973.
- [19] A. Rakotomamonjy, V. Guigue, "BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller," *IEEE Trans.on Biomed. Eng.*, vol.55, no.3, pp.1147-1154, March 2008.
- [20] A. Combaz1, N.V. Manyakov, N. Chumerin1, J. A. K. Suykens, M. M. Van Hulle, "Feature Extraction and Classification of EEG Signals for Rapid P300 Mind

زیرنویس‌ها

¹ Event Related Potentials² ElectroEncephaloGrphy³ Linear Discriminant Analysis⁴ Brain Computer Interface⁵ Independent Component Analysis

- ^۶ Communication rate
- ^۷ Support Vector Machine
- ^۸ Principle Component Analysis
- ^۹ Fisher Linear Discriminant
- ^{۱۰} Common Spatial Pattern
- ^{۱۱} Segmentation
- ^{۱۲} Local Iterative Replacement-LIR
- ^{۱۳} Curse of dimensionality
- ^{۱۴} Decimation
- ^{۱۵} Fisher Discriminant Criterion
- ^{۱۶} Fisher Discriminant Analysis
- ^{۱۷} Within-class covariance
- ^{۱۸} Between-class covariance
- ^{۱۹} Stepwise Linier Discriminant Analysis
- ^{۲۰} motor imagery
- ^{۲۱} Maximum A Posterior
- ^{۲۲} Leave One Out